



UNIVERSIDADE DE BRASÍLIA
INSTITUTO DE GEOCIÊNCIAS
CURSO DE ESPECIALIZAÇÃO EM GEOPROCESSAMENTO AMBIENTAL

**REDES NEURAIS E INTEGRAÇÃO DE DADOS DO SATÉLITE
SENTINEL-2 NO MAPEAMENTO DE USO E OCUPAÇÃO DO
SOLO**

Janailson Francisco da Silva

ARTIGO

BRASÍLIA
2016



UNIVERSIDADE DE BRASÍLIA
INSTITUTO DE GEOCIÊNCIAS
CURSO DE ESPECIALIZAÇÃO EM GEOPROCESSAMENTO AMBIENTAL

Janailson Francisco da Silva

**REDES NEURAIS E INTEGRAÇÃO DE DADOS DO SATÉLITE
SENTINEL-2 NO MAPEAMENTO DE USO E OCUPAÇÃO DO
SOLO**

**Artigo de especialização em
Geoprocessamento Ambiental
apresentada a banca examinadora
do Instituto de Geociências como
exigência para a obtenção do título
de especialista em
Geoprocessamento**

Aprovado em 09/12/2016

BANCA EXAMINADORA

Prof^a. Dr^a. Rejane Ennes Cicerelli (orientadora) _____

Prof. Dr. Henrique Llacer Roig _____

MSc. Kássia Batista de Castro _____

Redes neurais e integração de dados do satélite Sentinel-2 no mapeamento de uso e ocupação do solo

Resumo: As redes neurais são algoritmos baseados em aprendizado de máquina e tem demonstrado bons resultados em tarefas de reconhecimento de padrões em imagens orbitais. Este estudo objetiva avaliar a aplicação de uma rede neural artificial para mapeamento do uso e ocupação do solo no cerrado, integrando dados das bandas espectrais do satélite Sentinel-2 com um produto derivado, no caso o índice de vegetação normalizado, e mensurar o desempenho da classificação através de índices de exatidão. O instrumento imageador do satélite Sentinel-2 fornece 13 bandas que abrangem desde o visível até o infravermelho de ondas curtas. Neste trabalho foram utilizadas 11 bandas com resolução espacial de 10 e 20 m, juntamente com o índice de vegetação normalizado. O principal produto obtido foi o mapa de uso e ocupação do solo com 8 classes, sendo 4 naturais e 4 antrópicas. A acurácia temática calculada pelo índice Kappa foi de 0,77. A classificação por rede neural obteve um desempenho melhor do que a classificação produzida pelo método de máxima verossimilhança, o índice Kappa obtido na classificação MaxVer foi de 0,73. A imagem do Sentinel-2, aliada ao uso de uma rede neural, mostrou-se um bom insumo para execução desse tipo de mapeamento.

Palavras-chave: sensoriamento remoto, sentinel-2, backpropagation

Integration of sentinel-2 satellite data and neural nets for land use mapping

Abstract: the artificial neural networks are algorithms based on machine learning and it is being demonstrating good success in pattern recognition tasks on remote sensing imagery. Study aims to assess the application of an artificial neural network for land use mapping in Brazilian savanna, called as cerrado, integrating spectral bands from Sentinel-

2 satellite plus a derived product, the normalized vegetation index, measuring the performance of the mapping through a confusion matrix and its accuracy index. The Sentinel's multispectral sensor deliver 13 bands covering since the visible spectrum until the short wave infrared. At this work were applied 11 bands with 10 and 20 m spatial resolution and the normalized vegetation index. The main result was the land use map with 8 classes, 4 natural and 4 anthropic. The thematic accuracy estimated through Kappa index was 0.77. The artificial neural network classification worked better than the maximum likelihood classification, Kappa index of the last one was 0.73. Sentinel's imagery associated with an artificial neural network were considered good stuff to produce land use mappings.

Key words: neural net, remote sensing, sentinel-2, backpropagation

INTRODUÇÃO

O cerrado é o bioma que ocupa aproximadamente 23% do território brasileiro (Ribeiro & Walter, 2008), é o segundo bioma mais rico do Brasil em biodiversidade e sofre forte pressão proveniente de ocupação antrópica (Sano et al., 2009). O mapeamento das ocupações no cerrado é fundamental para diagnosticar distúrbios que possam gerar impactos negativos ao meio ambiente, o monitoramento contínuo das ocupações também fornece informações de apoio a tomada de decisão e definição de ações e políticas de ordenamento da ocupação territorial.

O avanço recente da tecnologia na área de sensoriamento remoto tem provocado mudanças significativas nas técnicas de processamento e análise do espaço geográfico. Entre os tópicos em evidência atualmente está o desenvolvimento de algoritmos baseados em aprendizagem de máquina (machine learning), como as redes neurais artificiais (RNAs). As RNAs tem sido aplicadas em trabalhos de classificação de uso e ocupação

do solo alcançando resultados melhores do que os métodos de classificação baseados em parâmetros estatísticos. Segundo Yool (1998), testes realizados com uma RNA e um classificador por máxima verossimilhança demonstrou que, a RNA obteve melhor resultado na classificação da maioria das classes, superando o classificador convencional.

Benediktsson et al., 1990; Chagas, 2008 e outros autores sustentam que as RNAs são mais eficientes nas tarefas de reconhecimento de padrões em imagens orbitais porque, inicialmente, não assumem nenhuma distribuição estatística acerca das classes, ao contrário dos classificadores baseados em estatística paramétrica, que pressupõem uma distribuição conhecida.

O objetivo do trabalho foi produzir o mapeamento de uso e cobertura do solo utilizando uma rede neural artificial com algoritmo backpropagation para treinamento da rede. Está incluído no escopo do estudo uma avaliação do desempenho da classificação através da matriz de confusão e cálculo do índice Kappa, assim como os outros parâmetros derivados da matriz. São analisadas comparativamente as classificações geradas pela rede neural e por um classificador que usa o método de máxima verossimilhança. Também é de interesse testar a integração dos dados das bandas espectrais juntamente com o NDVI, com intuito de avaliar a inclusão de um dado derivado para melhorar a classificação.

MATERIAIS E MÉTODOS

Área do estudo

O polígono mapeado neste estudo situa-se na porção leste do Distrito Federal, abrange uma pequena parte do estado de Goiás e uma pequena área no estado de Minas Gerais. Compreende a estação ecológica de Águas Emendadas e o campo de treinamento de Formosa-GO, totalizando 436.644 ha. Observa-se na imagem utilizada no estudo que a região possui alta variabilidade de ocupações, apresentando áreas naturais com

fitofisionomias do cerrado, fazendas com produção agrícola irrigada, cidades e núcleos urbanos com adensamento populacional diverso. Essa área foi selecionada por apresentar uma diversidade de ocupações que proporciona um desafio para o mapeamento, e por dispor dos dados necessários para a execução do escopo de trabalho proposto. A figura 1 mostra a localização do polígono de interesse.

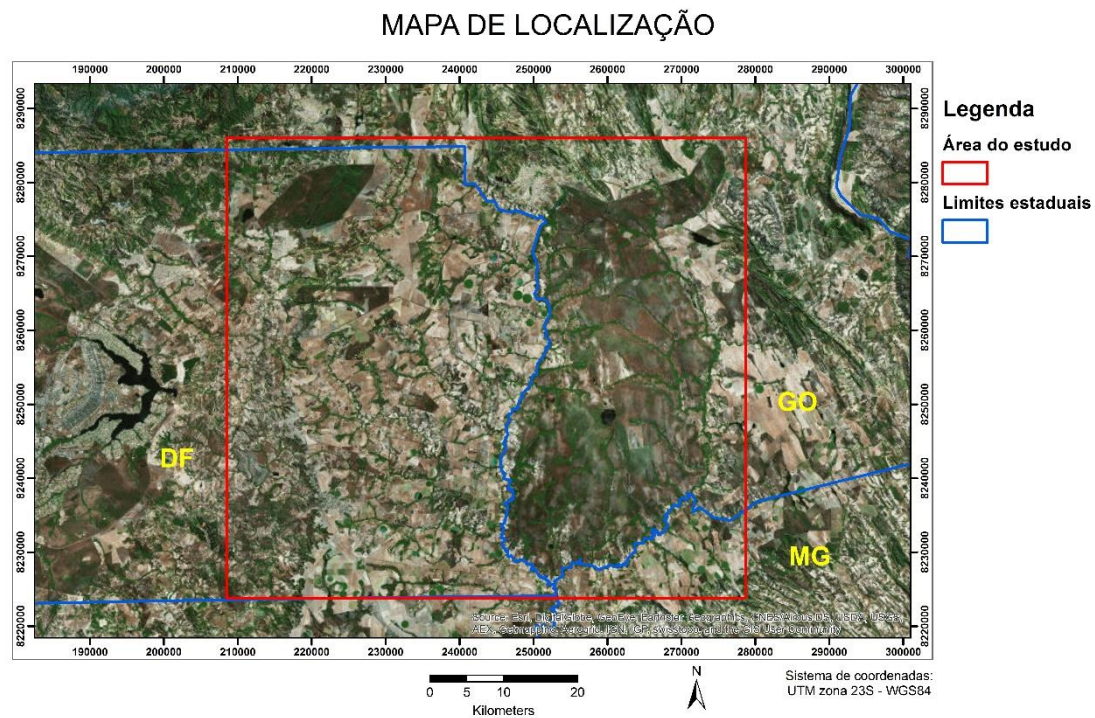


Figura 1. Mapa de localização da área de estudo

Metodologia do mapeamento

Na configuração de um levantamento de uso e ocupação do solo alguns princípios básicos devem ser observados (IBGE, 2013):

- A escala de mapeamento;
- Natureza da informação básica;
- A unidade de mapeamento e definição da menor área a ser mapeada;

- A nomenclatura das classes.

Este levantamento foi elaborado com base em uma escala 1:100.000. Essa definição está embasada na resolução espacial das imagens utilizadas, 20 m, e em padrões de mercado comumente utilizados, onde, imagens do satélite Landsat com resolução espacial de 30 m permitem a produção de mapeamentos com escala menor ou igual a 1:100.000.

A natureza da informação básica está relacionada a fonte principal de dados que será utilizada no mapeamento, o insumo básico para este trabalho foi uma imagem do satélite Sentinel-2A, adquirida pelo sensor óptico MSI – Multispectral Instrument, com data de imageamento em 08 de agosto de 2016. Este satélite é de propriedade da ESA – European Space Agency. Ele oferece boa resolução espectral com imagens em 13 bandas, 4 na faixa do visível (B1-443 nm; B2-490 nm; B3-560 nm; B4-665 nm), 5 na faixa do infravermelho próximo (B5-705 nm; B6-740- nm; B7-783 nm; B8-842 nm; B8A-865 nm; B9-940 nm) e 3 bandas na faixa do infravermelho de ondas curtas (B10-1375 nm; B11-1610 nm; B12-2190). A banda 8 tem largura de 115 nm e apresenta sobreposição com as bandas 5 e 6, que tem largura de 15 nm, e também com as bandas 7 e 8A com largura de 20 nm.

A resolução espacial é outra característica favorável sendo, 10 m para as bandas 2, 3, 4 e 8; 20 m para as bandas 5, 6, 7, 8A, 11 e 12. Nesse levantamento não foram utilizadas as bandas 1, 9 e 10 porque tem resolução espacial de 60 m e são mais indicadas para análise da atmosfera (ESA, 2015). A resolução radiométrica do Sentinel-2A é de 12 bits, possibilitando a diferenciação de até 4.095 níveis de cinza nas imagens. A figura 2 mostra o posicionamento das bandas ao longo do espectro.




Figura 2. Bandas espectrais do satélite Sentinel-2 e suas respectivas resoluções espaciais. Adaptado de Immitzer et al., 2016

A unidade de mapeamento é o objeto que representa a diversidade e homogeneidade da cobertura da terra, sendo a unidade de mapeamento mínima (UMM) a menor área com cobertura homogênea mapeável no levantamento (IBGE, 2013). A UMM está diretamente relacionada com a escala, porém, muitas vezes não é possível determiná-la levando em consideração apenas este fator. Alguns elementos do mundo real podem não ser representáveis na escala do mapeamento, mesmo tendo dimensões maiores que a UMM, enquanto outros podem ter tamanho menor e mesmo assim serem interpretados e representados no mapa (IBGE, 2013). Conforme recomendação do IBGE foi convencionado neste mapeamento uma UMM equivalente a um quadrado de 5 mm de lado, considerando a escala 1:100.000 isso é correspondente a uma área de 25 hectares.

A nomenclatura das classes seguiu o sistema sugerido pelo IBGE (2013), exceto para as áreas naturais. O sistema é dividido em 3 níveis sendo que o detalhamento aumenta a

cada nível, ele atende escalas até 1:100.000. No nível 1 estão as classes que representam as feições puramente de ocupação do solo, o nível 2 traz mais detalhe e tem classes que indicam atividades de uso do solo, e não somente ocupação, demonstrando que já existe um certo grau de interpretação envolvido. No nível 3 predominam as classes que representam atividades de uso do solo. Alcançar o grau de detalhamento do nível 3 não é possível somente com imagens de sensores remotos, faz-se necessário a inclusão de informações provenientes de outras fontes. De acordo com a escala proposta para o estudo as classes incluídas no mapeamento fazem parte do nível 1 e 2. Abaixo, a figura 3 exemplifica o sistema de classificação:

Nível I Classe	Digito II	Nível II Subclasse	Digito III	Nível III Unidades*
1 - Áreas Antrópicas Não Agrícolas	1,1	Áreas Urbanizadas	1.1.1	Vilas
			1.1.2	Cidades
			1.1.3	Complexos industriais
			1.1.4	Áreas urbano-industrial
			1.1.5	Outras áreas urbanizadas
	1.2	Áreas de Mineração	1.2.1	Minerais metálicos
			1.2.2	Minerais não metálicos

Figura 3. Sistema de classificação do uso e ocupação do solo dividido em níveis conforme grau de detalhamento.

Adaptado de IBGE (2013)

A definição das classes nas áreas com cobertura natural seguiu nomenclatura diferente daquela proposta pelo IBGE. De acordo com Ribeiro & Walter (2008), as fitofisionomias do cerrado podem ser agrupadas em 3 formações principais: formações florestais, formações savânicas e formações campestres. A formação florestal engloba a mata ciliar, mata de galeria, mata seca e o cerradão. A formação savânica é composta pelo cerrado sentido restrito, parque de cerrado, palmeiral e vereda. Já nas formações campestres estão incluídos o campo sujo, campo rupestre e campo limpo. O agrupamento faz-se necessário devido à dificuldade de diferenciar as fitofisionomias individualmente nas imagens de sensores remotos, assim sendo, neste estudo as áreas naturais foram classificadas em

formação florestal, formação savânica e formação campestre. A figura 4 ilustra as formações e as fitofisionomias do cerrado.




Figura 4. Fitofisionomias do cerrado agrupadas de acordo com as respectivas formações. Adaptado de Ribeiro & Walter, 2008

Dentro do polígono de estudo a classe cultura temporária apresenta pivôs irrigados com plantio em crescimento, parcelas onde já ocorreu a colheita e, provavelmente, ficou no solo restos de matéria orgânica da cultura, e parcelas com solo exposto. Devido ao comportamento espectral bastante distinto dessas ocupações foi necessário dividir as amostras de treinamento dessa classe em 3 grupos diferentes. Cada grupo configurou uma amostra de treinamento independente das outras. Isto fez-se necessário porque o processo de treinamento da RNA não seria bem-sucedido com uma única amostra contendo respostas espectrais tão diferentes para a mesma classe. Dessa forma, as amostras de treinamento representam 11 tipos de ocupações diferentes, sendo que 3 delas representam a mesma classe de uso do solo, nomeada cultura temporária. Após processada a classificação foi utilizada a ferramenta combine classes do Envi para agrupar os 3 tipos de ocupação referentes a classe cultura temporária. O resultado final são 08 classes de uso e ocupação do solo nomeadas e ilustradas na figura 5.

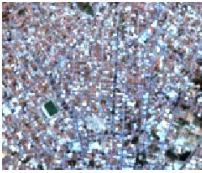
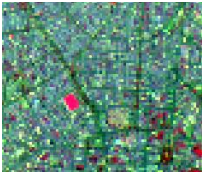










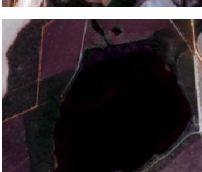
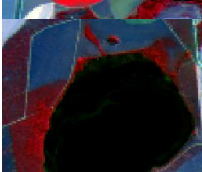
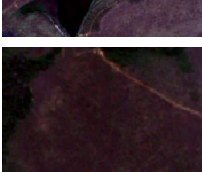

Classes	Composição cores naturais	Composição RGB 8,4,11
Area urbana		
Savana		
Silvicultura		
Pastagem		
Formação florestal		
Cultura temporária		
Corpo d'agua		
Formação campestre		

Figura 5. Exemplos das classes de uso e ocupação do solo e respectivas amostras em composição RGB

Processamento dos dados

Inicialmente foram baixadas 2 imagens do satélite Sentinel-2A através do site scientific hub da ESA, uma com data de 17/09/2016 e outra de 08/08/2016. A cena do mês 09 foi descartada porque apresentava algumas nuvens, ficando apenas a imagem do mês 08. Os dados do Sentinel-2A começaram a ser publicados no final de 2015 e não existe uma série histórica longa de imagens desse sensor.

A ESA disponibiliza o produto no nível de processamento L1C, correspondente a imagem ortorretificada com valores de reflectância no topo da atmosfera (TOA – top of atmosphere). Foi efetuado o pré-processamento das imagens para obter o nível L2A, onde os valores referem-se a reflectância de superfície (BOA – base of atmosphere), após o processo os valores ficam dentro do intervalo 0-1. Essa correção foi feita no modulo Sen2cor que é um componente do software Snap. O Snap é desenvolvido pela própria ESA, sendo a ferramenta indicada pela agência para efetuar esse processamento. Ao baixar as imagens também são disponibilizados vários outros dados, incluindo arquivos .xml com toda a parametrização necessária para efetuar a correção. O processamento é feito de acordo com a resolução espacial das bandas, como foram utilizadas bandas com resolução de 10 e 20 m o processo foi executado 2 vezes. Para possibilitar o uso de todas as bandas simultaneamente na rede neural as bandas com resolução de 10 m foram reamostradas para 20 m. Esse procedimento foi executado no software Snap utilizando um algoritmo “vizinho mais próximo” padrão.

As imagens processadas no nível L2A foram exportadas para o Envi e recortadas de acordo com o polígono da área de interesse, em seguida foram empilhadas em arquivo único com o auxílio da ferramenta layer stacking. Na etapa seguinte foi executada a coleta de amostras para o treinamento da rede neural. Inicialmente foram coletados

aproximadamente 1.500 pixels de cada classe, porém, os primeiros testes de treinamento da rede não mostraram bons resultados. Optou-se por aumentar a quantidade de amostras e após vários ajustes cada classe ficou com aproximadamente 3.000 pixels. As redes neurais funcionam melhor com uma massa maior de amostras de treinamento, quanto mais dados estiverem disponíveis para o processo de treinamento da rede melhor será o resultado da classificação (Benediktsson et al., 1990).

Durante a coleta buscou-se selecionar amostras com pixels puros que representassem o comportamento espectral típico das classes. Foram criadas 2 composições RGB sobre as quais as amostras foram coletadas, uma com as bandas do visível em cores naturais, RGB 4-3-2, e outra com a composição RGB 8-4-11, que ressalta as formações florestais fotossinteticamente ativas. As amostras de treinamento foram selecionadas analisando essas 2 composições.

A etapa seguinte consistiu no treinamento da rede neural artificial e a produção da classificação propriamente dita. Nesta etapa foi utilizada a ferramenta neural net do software Envi para produção da classificação. As RNAs são modelos que procuram simular o funcionamento do neurônio biológico e são bastante aplicadas em tarefas de reconhecimento de feições. São estruturadas em camadas, geralmente tem-se uma camada de entrada, uma ou mais camadas intermediárias (ocultas) e mais uma camada de saída. As camadas são compostas pelos neurônios e a quantidade de neurônios em cada camada é variável. Os neurônios de todas as camadas são conectados e cada conexão possui pesos dinâmicos que são aplicados aos dados.

Nesse estudo foi utilizada uma RNA do tipo feed forward com 3 camadas aliada ao algoritmo de treinamento backpropagation. Esse tem sido o tipo de RNA usualmente empregada nas aplicações de sensoriamento remoto (Diverio et al., 2003). Sua arquitetura

consiste em uma camada de entrada, uma oculta e outra de saída. RNAs com essa topologia operam com fluxo de dados em sentido único, da camada de entrada para a de saída (Paola & Schowengerdt, 1997).




Figura 6. Estrutura de uma rede neural feed forward de 3 camadas. Adaptado de cérebromente.org.br

O funcionamento da rede inicia com a entrada das amostras coletadas contendo os dados das bandas espectrais. A primeira camada recebe os dados, esse nível não efetua nenhuma operação ele apenas distribui os dados para a camada seguinte. Na camada oculta cada neurônio tem dupla função, eles executam a soma dos valores ponderados pelo peso associado a conexão existente entre a camada oculta e a de entrada, e passam os dados por uma função de ativação. Essa função tem um valor de limiar que é utilizado como parâmetro de ativação, se o valor de saída estiver acima do limiar de ativação os dados seguem para a última camada, caso contrário nenhuma saída é gerada. A camada de saída entrega as categorias geradas pela RNA, no caso as classes de uso e ocupação do solo (Paola & Schowengerdt, 1997).




Figura 7. Neurônio artificial da camada oculta de uma rede neural feed forward. Adaptado de cérebromente.org.br

O algoritmo backpropagation compara a saída gerada pela RNA com a amostra de entrada e calcula uma diferença. Esta diferença é representada matematicamente pelo RMSE – root mean square error. A seguir uma parte dessa diferença é retro propagada na rede a partir da camada de saída ajustando os pesos das conexões entre os neurônios (Benediktsson et al., 1990). O ajuste dos pesos é aplicado proporcionalmente em cada neurônio, assim o neurônio que mais contribuiu para o RMSE receberá maior ajuste nos pesos de suas conexões, visando aproximar o resultado de saída do resultado esperado. Esse processo é repetido de forma iterativa sendo a quantidade de iterações um dos principais parâmetros a ser definido pelo usuário para alcançar um bom treinamento da rede neural (Benediktsson et al., 1990).

Em um treinamento bem-sucedido o RMSE decai a medida que a quantidade de iterações aumenta, atingindo um ponto de estabilidade a partir do qual se mantém praticamente constante. Aumentar a quantidade de iterações além desse ponto não traz melhoria para a classificação e demanda mais tempo de processamento (Paola & Schowengerdt, 1997).

Outro parâmetro importante é a taxa de treinamento, ela representa a velocidade de aprendizado da RNA, ao aumentar a taxa uma maior proporção do erro aferido ao final da iteração será utilizado para o ajuste dos pesos na iteração seguinte (Paola &

Schowengerdt, 1997). Quanto mais alta a taxa mais rápido será o processo de treinamento, porém, uma taxa muito alta pode levar a um ajuste brusco nos pesos das conexões provocando maior erro na camada de saída, e consequentemente dificultando a convergência do RMSE para baixo (Paola & Schowengerdt, 1997). Por outro lado, taxas muito baixas podem demandar mais tempo e recurso computacional no processo de treinamento. Para uma RNA feed forward de 3 camadas como a utilizada nesse estudo, pode-se trabalhar com taxas mais baixas pois a complexidade da rede não é alta.

Uma característica interessante das RNAs é a possibilidade de utilização de outros dados para classificação e não somente as bandas espectrais. Os dados podem ser produtos derivados das bandas ou informações de outra natureza (Benediktsson et al., 1990). Este trabalho integrou o NDVI na classificação, fornecendo um parâmetro adicional para RNA. O NDVI utilizado foi calculado no software Envi.

No total foram geradas 32 versões da classificação até que fosse alcançada a configuração ideal da RNA, a maioria das classificações foram produzidas com as bandas 2, 3, 4, 8, 11 e 12. Uma versão foi produzida utilizando ao invés da banda 8 as bandas 5, 6, 7 e 8A, que tem melhor resolução espectral do que a banda 8, porém, pior resolução espacial. As bandas 5, 6, 7, 8 e 8A estão posicionadas na mesma faixa do espectro infravermelho, gerando sobreposição. Essa versão foi nomeada como teste de bandas e o intuito foi verificar qual classificação apresentaria melhor acurácia.

Outra versão foi criada adicionando o NDVI junto com as bandas 2, 3, 4, 8, 11 e 12, para verificar se a inclusão deste parâmetro melhoraria a qualidade do mapeamento, essa classificação foi chamada de teste NDVI. Uma outra versão foi produzida a partir das bandas 2, 3, 4, 8, 11 e 12, através do método de máxima verossimilhança. Utilizando a ferramenta Maximum Likelihood do Envi a classificação foi produzida e comparada com

a classificação gerada pela rede neural, que inclui as mesmas bandas mais o NDVI, afim de analisar qual método apresentaria melhor resultado. Essa avaliação foi chamada de teste MaxVer.

Após produzida a classificação foi aplicado um processo de generalização utilizando a ferramenta classification aggregation do Envi. Esse procedimento foi executado para compatibilizar a classificação com o parâmetro de unidade mínima mapeável. Agrupamentos de pixels com menos de 25 unidades foram incorporados a classe adjacente de maior área.

A exatidão da classificação foi mensurada com apoio da matriz de confusão e os índices dela derivados. Esse tem sido o método padrão para estimar a exatidão temática de mapas de uso e ocupação do solo (Figueiredo, 2007). Para geração da matriz foram selecionados 74 pontos pelo método estratificado não alinhado visando identificação da verdade terrestre. Os pontos foram distribuídos de forma aleatória na área através da ferramenta sampling, do ET Geo Wizards, módulo incorporado no ArcGIS. A figura 8 mostra a localização dos pontos dentro da área de estudo.

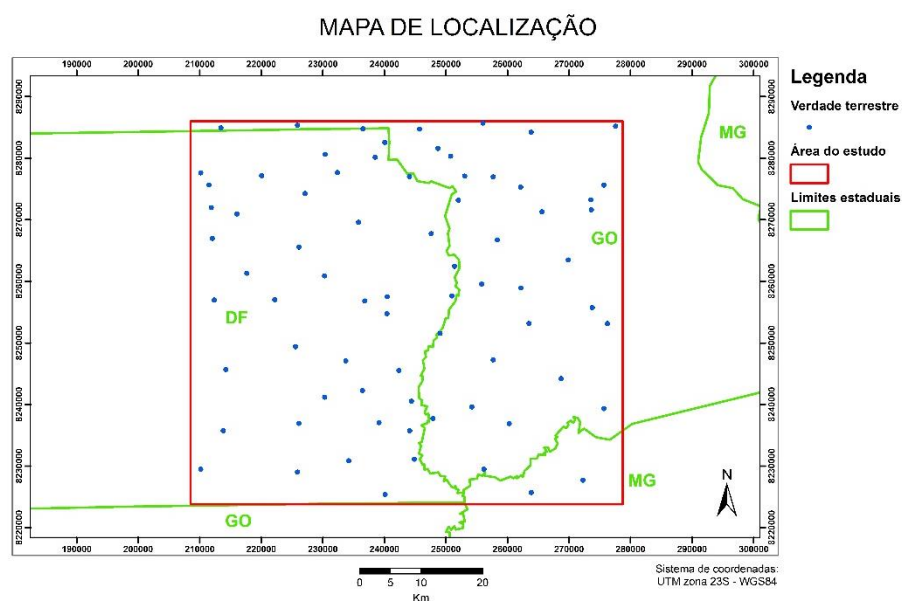


Figura 8. Distribuição dos pontos de coleta da verdade terrestre para validação das classificações

A verdade terrestre foi determinada a partir de imagem de levantamento aerofotogramétrico realizado pelo Governo do Distrito Federal em 2015. As fotos aéreas têm resolução espacial de 25 cm possibilitando a clara identificação da feição presente nos pontos selecionados. O levantamento aéreo cobre somente o DF e o polígono de interesse abrange uma pequena parte dos estados de Goiás e Minas gerais. Na área fora do DF foram utilizadas para identificação da verdade terrestre imagens do satélite RapidEye com resolução espacial de 5 m. A maioria das classificações produzidas pela rede neural foram avaliadas com apoio da matriz de confusão. Algumas classificações foram descartadas por avaliação visual e outras por baixo desempenho no processo de treinamento da rede.

RESULTADOS E DISCUSSÕES

Na etapa de treinamento da RNA aproximadamente 32 combinações diferentes de parâmetros foram testadas, o melhor resultado foi obtido na 26ª tentativa utilizando 2.000 iterações e taxa de treinamento de 0,2. O gráfico da figura 9 ilustra a evolução do RMSE ao longo desse processo de treinamento.




Figura 9. Gráfico do RMSE resultante de treinamento bem-sucedido de rede neural

Observa-se que a curva decai rapidamente nas primeiras iterações e logo torna-se constante, demonstrando que o RMSE convergiu para um patamar estável. Nesse caso, aumentar o número de iterações não implicou em melhora no processo de treinamento. Abaixo, o gráfico da figura 10 mostra um exemplo em que o processo de treinamento não foi bem-sucedido. Nota-se que ocorreram picos no RMSE ao longo das iterações mostrando que os pesos da RNA sofreram ajustes bruscos e não convergiram de forma linear para um patamar estável, provocando um resultado de saída com alta diferença em relação ao desejado. No gráfico da figura 9 o RMSE ao final do treinamento ficou abaixo de 0,2, enquanto que na figura 10 não foi menor que 0,3.




Figura 10. Gráfico mostrando picos do RMSE ao longo do processo de treinamento

Na avaliação do teste de bandas constatou-se que a utilização da banda 8, que abrange uma largura maior do espectro infravermelho e tem melhor resolução espacial, resultou em uma classificação com melhor acurácia. Foi obtido um índice Kappa de 0,75 e um índice global de 0,80. Na classificação sem a banda 8 e com as bandas 5, 6, 7, e 8A, que tem melhor resolução espectral, o resultado foi de 0,70 e 0,76 para os índices Kappa e global respectivamente. Segundo estudos feitos por Immitzer (2016), as bandas 5, 6, 7 e

8A tem melhor aplicação na diferenciação de espécies florestais devido a capacidade de detalhamento das respostas espectrais na faixa do infravermelho próximo. Vale ressaltar que ambas as classificações utilizaram as mesmas amostras de treinamento e validação, assim como a mesma configuração da rede neural.

Ao analisar os resultados do teste NDVI nota-se que a inclusão desse parâmetro não teve impacto significativo no sentido de melhorar os índices Kappa e global do mapeamento. A classificação sem o NDVI atingiu 0,75 e 0,81 para os índices Kappa e global, respectivamente. Ao integrar o parâmetro de vegetação na rede neural a classificação produzida obteve 0,77 e 0,82 para os mesmos índices.

Os índices Kappa e global obtidos no teste MaxVer foram avaliados e o mapa gerado pela rede neural apresentou melhor acurácia em relação a classificação produzida pelo algoritmo de máxima verossimilhança. O índice Kappa obtido pela RNA alcançou 0,77 e o global 0,82. Os mesmos índices resultantes da classificação MaxVer foram 0,73 e 0,78, respectivamente.

Avaliando individualmente a acurácia das classes foi possível detalhar melhor o desempenho de cada classificador. A RNA apresentou desempenho mais baixo na classe pastagem com acurácia do produtor de 47%. Ocorreu maior confusão com a classe cultura temporária. Já no caso do MaxVer a menor acurácia foi encontrada na classe campestre, 55% foi a taxa de acerto do classificador. A confusão ocorreu principalmente com a classe pastagem, e em menor nível com as classes savana e área urbana que tiveram áreas classificadas como campestre indevidamente. Em ambos os métodos a classe pastagem representou um desafio para os classificadores.

Nos dois métodos as classes silvicultura e corpo d'água foram 100% classificadas corretamente. A segunda melhor performance da rede neural foi na classe área urbana

que atingiu 90% para a acurácia do produtor e erro de comissão de 17%. Para o classificador MaxVer o segundo melhor desempenho ocorreu na classe formação florestal, a acurácia do produtor foi de 83% e não houve erro de comissão. As tabelas abaixo mostram os erros de comissão e omissão assim como a acurácia do produtor e usuário em todas as classes para os dois métodos de classificação.

1A.					1B.				
Classes	Comissão %	Omissão %	Comissão (Pixels)	Omissão (Pixels)	Classes	Prod. Ac. %	User Ac. %	Prod. Ac. (Pixels)	User Ac. (Pixels)
Campestre	20,9	29,8	130/623	209/702	Campestre	70,2	79,1	493/702	493/623
CorpoAgua	0,0	0,0	0/122	0/122	CorpoAgua	100,0	100,0	122/122	122/122
CulturaTemp	19,8	9,5	223/1128	95/1000	CulturaTemp	90,5	80,2	905/1000	905/1128
Florestal	0,6	17,4	2/349	73/420	Florestal	82,6	99,4	347/420	347/349
Pastagem	53,2	52,7	100/188	98/186	Pastagem	47,3	46,8	88/186	88/188
Silvicultura	0,0	0,0	0/162	0/162	Silvicultura	100,0	100,0	162/162	162/162
Savana	29,0	27,9	36/124	34/122	Savana	72,1	71,0	88/122	88/124
AreaUrbana	17,5	10,1	38/217	20/199	AreaUrbana	90,0	82,5	179/199	179/217

Tabelas 1A. e 1B. Parâmetros que indicam a acurácia da classificação usando redes neural

2A.					2B.				
Classes	Comissão %	Omissão %	Comissão (Pixels)	Omissão (Pixels)	Classes	Prod. Ac. %	User Ac. %	Prod. Ac. (Pixels)	User Ac. (Pixels)
Campestre	16,09	45,01	74/460	316/702	Campestre	54,99	83,91	386/702	386/460
CorpoAgua	0	0	0/122	0/122	CorpoAgua	100	100	122/122	122/122
CulturaTemp	12,51	13,3	124/991	133/1000	CulturaTemp	86,7	87,49	867/1000	867/991
Florestal	0	16,9	0/349	71/420	Florestal	83,1	100	349/420	349/349
Pastagem	66,1	36,02	232/351	67/186	Pastagem	63,98	33,9	119/186	119/351
Silvicultura	0	0	0/162	0/162	Silvicultura	100	100	162/162	162/162
Savana	51,5	33,61	86/167	41/122	Savana	66,39	48,5	81/122	81/167
AreaUrbana	36,01	0	112/311	0/199	AreaUrbana	100	63,99	199/199	199/311

Tabelas 2A. e 2B. Parâmetros que indicam a acurácia da classificação usando MaxVer

O mapa final da classificação de uso e ocupação do solo obtido pelo classificador por rede neural é apresentado na figura 11. A acurácia calculada pelo índice Kappa foi de 0,77 e o índice global foi de 82%. As bandas utilizadas foram 2, 3, 4, 8, 11 e 12 e também foi incluído o NDVI.

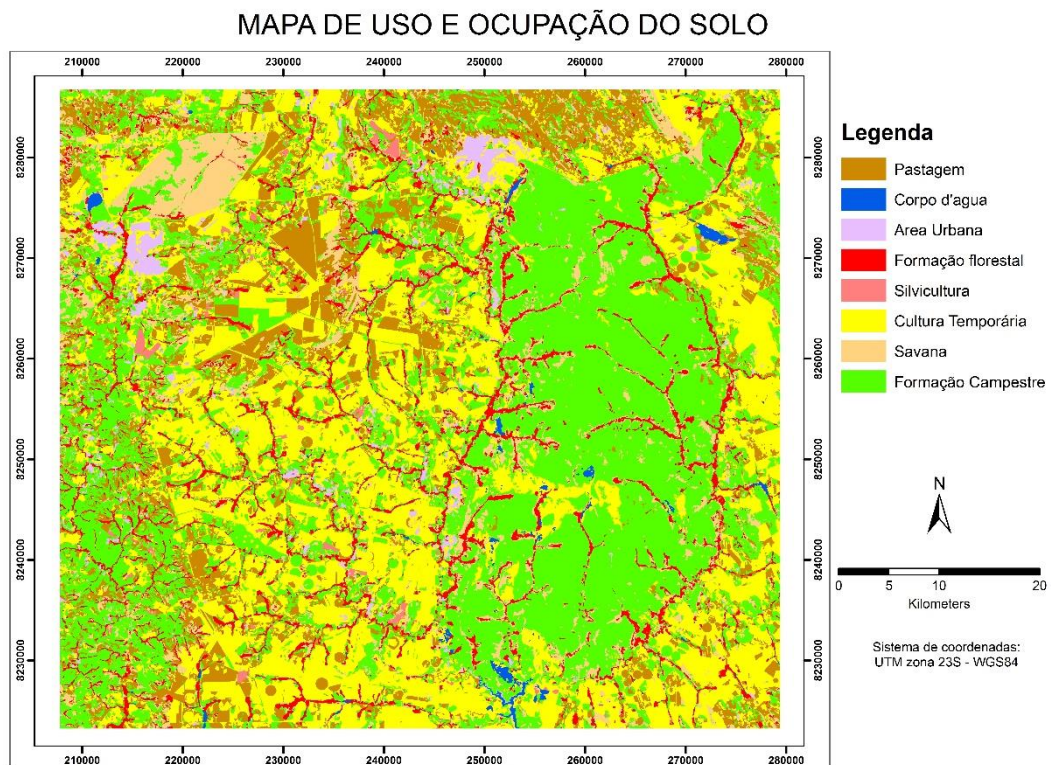


Figura 11. Mapa com a classificação final produzida pela rede neural

CONCLUSÕES

1. Foi constatado que a utilização da banda 8 na rede neural resulta em uma classificação melhor do que usando as bandas 5, 6, 7 e 8A, para os alvos analisados.
2. A inclusão do NDVI na rede neural juntamente com as bandas espectrais não proporcionou melhora significativa na classificação.
3. O classificador por rede neural do tipo feed forward obteve melhor resultado na classificação em relação ao algoritmo por máxima verossimilhança.
4. As imagens do satélite Sentinel-2 mostram-se insumos de muito boa qualidade para utilização em mapeamentos de uso e ocupação.

LITERATURA CITADA

- Benediktsson, J. A.; Swain, P. H.; Ersoy, O. K. Neural network approaches versus statistical methods in classification of multisource remote sensing data. IEEE Transactions on Geoscience and Remote Sensing, v.28, n.4, p.540-552, 1990.
- Chagas, C. S.; Vieira, C. A. O.; Filho, E. I. F. Utilização de redes neurais artificiais na classificação de níveis de degradação em pastagens. Revista Brasileira de Engenharia Agrícola e Ambiental, v.13, n.3, p.319-327, 2009.
- Diverio, V. T.; Formaggio, A. R.; Shimabukuro, Y. Identificação de áreas desflorestadas na Amazônia através de uma rede neural artificial utilizando imagens fração derivadas dos dados do IR-MSS/CBERS. In: Simpósio Brasileiro de Sensoriamento Remoto, 11, 2003, Belo Horizonte. Anais, 2003.
- ESA - European Space Agency. Sentinel-2 user handbook. 1.ed. Darmstadt: ESA, 2015. 64p
- Figueiredo, G. C. Exatidão posicional e temática de imagens orbitais. Viçosa: UFV, 2007. 104p. Dissertação Mestrado
- IBGE - Instituto Brasileiro de Geografia e Estatística. Manual técnico de uso da terra. 3.ed. Rio de Janeiro: IBGE, 2013. 171p
- Immitzer, M.; Vuolo, F.; Atzberger, C. First experience with Sentinel-2 data for crop and tree species classifications in central Europe. Remote sensing, v.8, n.3, 2016.
- Paola, J. D.; Schowengerdt, R. A. The effect of neural-network structure on a multispectral land-use/land-cover classification. Photogrammetric engineering & remote sensing, v.63, n.5, p.535-544, 1997.

Ribeiro, J. F.; Walter, B. M. T. As principais fitofisionomias do Bioma Cerrado. Cerrado: ambiente e flora. Embrapa Cerrados, Planaltina. p. 151-212, 2008.

Sano, E. E.; Rosa, R.; Brito, J. L. S.; Ferreira, L. G. Land cover mapping of the tropical savanna region in Brazil. Environmental Monitoring and Assessment, v.166, n.1, p.113-124, 2009.

Yool, S.R. Land cover classification in rugged areas using simulated moderate-resolution remote sensor data and an artificial neural network. International Journal of Remote Sensing, v.19, n.1, p.85-96, 1998.